

Faster-RCNN을 이용한 열화상 이미지 처리 및 합성 기법

신기철¹, 이준수², 김주식³, 김주형⁴, 권장우^{5*}

¹인하대학교 전기컴퓨터공학과 학생, ²인하대학교 기계공학과 학생, ³인하대학교 기계공학과 교수,
⁴한국수력원자력(주) 디지털솔루션부 대리, ^{5*}인하대학교 전기컴퓨터공학과 교수

Thermal Image Processing and Synthesis Technique Using Faster-RCNN

Ki-Chul Shin¹, Jun-Su Lee², Ju-Sik Kim³, Ju-Hyung Kim⁴, Jang-woo Kwon^{5*}

¹Student, Dept. of Electronic Computer Engineering, Inha University

²Student, Dept. of Mechanical Engineering, Inha University

²Professor, Dept. of Mechanical Engineering, Inha University

²Manager, Dept. of Digital Solution Section Hydro&Nuclear Power Company

^{3*}Professor, Dept. of Electronic Computer Engineering, Inha University

요약 본 논문에서는 열화상 이미지에서의 열 데이터 추출 및 해당 데이터를 사용한 발열 설비 탐지 향상 기법을 제안한다. 주요 목표는 열화상 이미지에서 바이트 단위로 데이터를 해석하여 열 데이터와 실화상 이미지를 추출하고 해당 이미지와 데이터를 합성한 합성 이미지를 딥러닝 모델에 적용하여 발열 설비의 탐지 정확도를 향상시키는 것이다. 데이터는 한국수력원자력발전소 설비 데이터를 사용하였으며, 학습 모델로는 Faster-RCNN을 사용하여 각 데이터 그룹에 따른 딥러닝 탐지 성능을 비교 평가한다. 제안한 방식은 Average Precision 평가에서 기존 방식에 비해 평균 0.17 향상 되었다.본 연구는 이로서 국가 데이터 기반 열화상 데이터와 딥러닝 탐지의 접목을 시도하여 유효한 데이터 활용도 향상을 이루었다.

주제어 : 이미지 합성, 딥러닝, 열화상 이미지, 이미지 처리, 이상 진단

Abstract In this paper, we propose a method for extracting thermal data from thermal image and improving detection of heating equipment using the data. The main goal is to read the data in bytes from the thermal image file to extract the thermal data and the real image, and to apply the composite image obtained by synthesizing the image and data to the deep learning model to improve the detection accuracy of the heating facility. Data of KHNP was used for evaluation data, and Faster-RCNN is used as a learning model to compare and evaluate deep learning detection performance according to each data group. The proposed method improved on average by 0.17 compared to the existing method in average precision evaluation.As a result, this study attempted to combine national data-based thermal image data and deep learning detection to improve effective data utilization.

Key Words : Image Fusion, Deep Learning, Thermal Image, Image Processing, Abnormal Diagnosis

*This study was supported in part by the Korea Hydro& Nuclear Power Co., Ltd., Republic of Korea(No. 2018-Tech-07)
(본 논문은 KOREA HYDRO&NUCLEAR POWER CO. LTD(No. 2018-Tech-07)의 지원을 받아 수행되었음)

*Corresponding Author : Jang-Woo Kwon(jwkwon@inha.ac.kr)

Received October 12, 2021

Revised December 1, 2021

Accepted December 20, 2021

Published December 28, 2021

1. 서론

1.1 연구 배경

최근 국내의 산업 현장에서 딥러닝을 적용한 업무 자동화 및 문제 해결을 위한 연구가 많이 진행되고 있다. 이에 따라 열화상 측정이 필요한 산업현장도 딥러닝 기술을 적용하고 있다[1]. 그러나 실제 현장에서 측정된 열화상 이미지로는 만족할 수 있는 딥러닝 탐지 정확도를 가지기 어려우며 이는 열화상 이미지가 지닌, 실화상 이미지와 차이에서 기인한다.

열화상 카메라는 일반적으로 실화상 카메라에 비해 픽셀 별 색상이 제한되어 있다. 이는 곧 딥러닝 학습에서 데이터의 특징을 제한적으로 학습하는 것과 같으므로, 같은 딥러닝 탐지 모델을 사용하더라도 모델의 성능이 일반 이미지, 즉 실화상 이미지에 비해 낮을 수밖에 없는 요인 중 하나이다.



Fig. 1. Blur thermal image

Fig. 1은 색상 특징 제한이 생긴 열화상 이미지 샘플로써 배경과 발열이 비슷해 물체 식별이 어려운 것을 볼 수 있다.

열화상 이미지에서의 발열에 따른 색상 표현은 측정 장치 및 측정 숙련도에 따라 변하지만 현실적으로 측정자의 숙련도 문제 및 안전 촬영 문제로 인해 실제적인 데이터 품질 향상은 어렵다.

기존 딥러닝 탐지 연구는 실화상 이미지 위주였으며, 열화상 이미지 기반 딥러닝 연구는 데이터 취득 문제로 인해 활발한 연구가 진행되고 있지 않다. 본 연구는 이미지 처리 및 합성을 통하여 열화상 이미지에서의 열 값을 하나의 특징으로서 딥러닝 탐지 향상에 접목시키고자 한다.

1.2 연구 내용 및 의의

한국수력원자력발전소에서는 발열 설비의 이상 진단을 위해 주기적으로 설비를 촬영하여 데이터베이스에 저장하고 사용하였으나 데이터 품질 문제로 딥러닝 기반 이상 진단은 진행에 어려움이 있다. 이에 따라본 연구에서는 기존 열화상 이미지를 사용한 딥러닝 기반 이상 진단 성능을 다음과 같은 과정을 통해 개선하고자 하며, 아래 4가지 과정을 진행한다.

첫째, 열화상 이미지 파일(JPEG) 내부에 바이트 단위로 저장되어 있는 열 데이터와 실화상 데이터 및 필요한 환경 정보를 추출 한다

둘째, 이미지 전처리 및 이미지 합성을 실행하여 열화상 원본 이미지, 추출된 실화상 이미지, 재구성된 열화상 이미지, 열과 실화상을 합성한 합성 이미지의 4가지 타입의 이미지 데이터를 제작한다

셋째, 4가지 타입의 데이터를 Faster-RCNN에서 학습하고, 각 설비 별 탐지 정확도를 비교한다. 정확도 비교 지표로 Average Precision(AP)를 사용한다.

넷째, 측정 불량 판정을 받은 이미지를 처리하여 딥러닝 기반 설비 진단에 사용 가능한 데이터로 재활용할 수 있는 지를 실험한다. 이를 통해, 한국수력원자력발전소의 이상 탐지를 위한 설비 이미지 데이터를 측정 효율을 높인다.

이를 통하여 본 논문은 열화상 이미지 처리 및 합성을 통해 발열 설비의 Faster-RCNN 기반 탐지 정확도를 향상하고 이를 통한 열 데이터 활용성을 높이는 방안을 제안한다.

1.3 관련 연구

1.3.1 Thermal Image Processing

현재 산업 현장에서 열화상 데이터의 주 사용처는 발열 물체의 비파괴 이상 진단이다[2]. Fig. 2는 이미지 기반 비파괴 진단의 대표적 방법인 신호 해석(Signal Analysis)을 이용한 진단을 보인다[3].

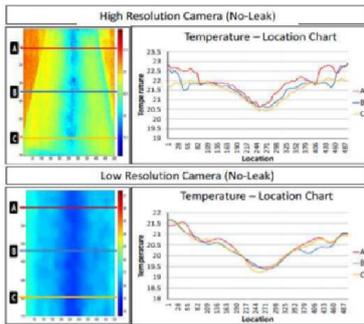


Fig. 2. Thermal diagnosis through signal analysis

딥러닝 기술의 부상 후, 기존의 신호적인 해석보다 색상값과 고유 측정값을 가진 4차원 데이터로 주로 해석된다. 이러한 해석이 가능한 또 다른 이미지가 색상값과 깊이 측정값을 가진 RGB-Depth 이미지이다.

RGB-Depth 이미지는 자율형 자동차 및 보행자 인식분야에서 많은 연구가 이뤄지고 있다[4]. Fig. 3은 보행자 인식을 위한 RGB-Depth 이미지를 나타낸 그림으로써 좌측의 RGB이미지에 비해 우측의 Depth 이미지가 보행자 인식 면에서 더 인식하기 편한 차이를 보여주고 있다.



Fig. 3. RGB-Depth image Feature

본 연구에서는 RGB-Depth 이미지를 사용한 연구 사례를 바탕으로 이미지 전처리 및 이미지 합성을 시도한다.

1.3.2 Image Fusion

이미지 합성은 주로 많은 실험 데이터가 요구되는 영상 분석에서 사용된다. 국내 이미지 합성 연구는 픽셀 조합을 사용한 필터 방식이 주류였으나, 딥러닝의 발달과 함께 이미지 합성을 통한 딥러닝 객체 탐지 보조가 주목을 받고 있다[5].

기존 이미지 합성은 주로 증강을 통한 이미지 특징을 인위적으로 증폭하고, 해당 특징이 끼치는 학습 영향에 대한 분석에 집중하였다. 본 연구는 그러한 분석에 ROI-Filtering을 통하여 열 값이 더해진 픽셀 별 색상값이 물체 탐지에 좋은 특징으로 해석되는지를 실험한다.

1.3.3 Region based CNN(RCNN)

Region based CNN은 이미지 내 물체 탐지 알고리즘의 핵심 알고리즘이며[6] 2015년 발표된 Faster-RCNN, 2017년 발표된 Mask-RCNN으로 대표되는 물체 탐지 모델에 빈번히 사용되었다[7].

Faster-RCNN은 이미지내의 물체의 위치를 잡아내고(Localization), 해당 물체가 무엇인지(Classification)를 end-to-end 방식으로 진행하는 모델이다. Faster-RCNN은 기존 딥러닝 기반 이미지 내 물체 탐지에서 최대 난제 중 하나였던 ‘효율적인 물체 탐지를 위한 적절한 관심영역(Region of Interest) 선정’을 앵커(Anchor)를 중심으로 RPN(Region Proposal Network)을 구성하는 방식으로 해결하였다.

2. 본론

2.1 연구 내용

본 연구의 목적은 딥러닝 기반 열화상 이미지에서의 발전소 설비 탐지 성능을 향상하고, 측정 불량 이미지를 가공하여 데이터 활용도를 높이는 것이다.

Fig. 4는 본 연구의 전체 프로세스를 묘사한다. 연구 프로세스는 크게 메타 데이터 추출, 이미지 전처리 및 합성, Faster-RCNN 학습으로 그리고 불량 데이터 활용 시도를 포함한 성능 평가로 구성된다.

2.2.1 메타 데이터 추출(Meta Data Extraction)

기존 한국수력원자력발전소에서 설비 진단 자동화에 사용한 열화상 이미지는 Fig. 1과 같이 불필요한 카메라 정보가 이미지에 존재하며, mAP(mean average precision)가 0.5인 낮은 탐지 성능을 보인다.

이를 해결하기 위해 열화상 이미지의 메타데이터를 추출하여 탐지에 유리한 입력 데이터를 사용한다.

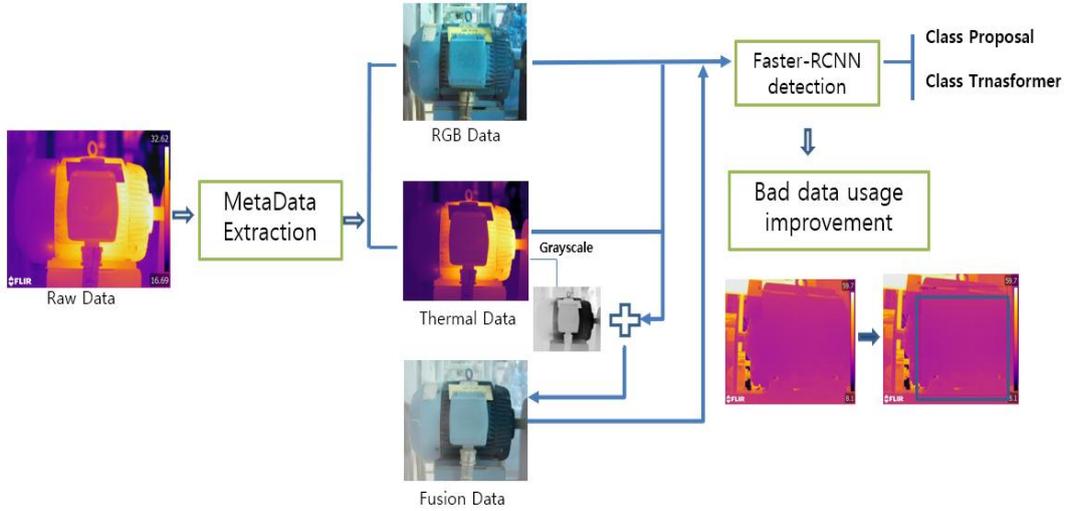


Fig. 4. Schematic of the whole process

한국수력원자력발전소에서 사용하는 열화상 측정 장치는 FLIR 사의 'FLIR T-series'이며 저장 파일 포맷은 'FLIR'이다. FLIR 포맷의 주요 정보는 태그로 구분되며 실험에 필요한 태그들은 Table 1에 나타나 있다. Table 1은 FLIR 공식 사이트에서 제공하는 메타 데이터 자료를 바탕으로 작성되었다[8].

Table 1. Flir Target Tags

Tag ID / Index2	Tag Name	Writ able	Values/ Notes
header	FFFHeader	-	FLIR Header Tags
0x000e	Embedded Image	-	EmbeddedImage Tags
0x002a	PiP	-	-
0x002e	Parameter Info	-	-
0x0020	CameraInfo	-	-
0x0021	Measurementinfo	-	-

TagID/Index2는 파일 내의 각 태그의 주소값이다. TagName은 태그 이름이며, Writable는 수정 가능 여부를 의미한다. Values/Notes는 해당 태그에 대해 추가적으로 명시되어야 하는 사항을 의미한다.

Def ExtractEmbeddedImage ($\in put$)

Tag = - EmbeddedImage

Ifuse Thumbnail :

Tag = - ThumbnailImage

imgStream = readBytes ($\in put, Tag$)

Img = imgOpen(*imgStream*)

imgData = saveasNumpy(*Img*)

return imgData

위 수식은 태그를 사용한 데이터 추출 작업은 파이썬 수도 코드이며 비슷한 형태로 열 데이터 추출, 실화상 데이터 추출, 환경 정보 추출 세 작업을 진행한다.

2.2.2 이미지 처리 및 합성(Image Processing & Image Fusion)

추출한 메타 데이터는 16bit 값이므로, 해석 가능한 섭씨 온도 값 치환하기 위해서 캘리브레이션 조정 값과 방사율(Emissivity), 측정 거리(Distance), 공기 온도 (Atmospheric temperature)와 같은 측정 장치의 설정값을 이용하여 계산한다[9].

$$C = PB / \ln(PR_1 / PR_2 * (raw_{obj} + PO)) + PF - 273.18$$

치환식은 위와 같으며, 각 인자에 대한 설명과 기본 값은 Table 2에 나타나 있다.

Table 2. raw to celsius parameters

Data	Notes	default
C	Celcius value	-
PB	PlankB calibration contant from FLIR file	1501
PR1	PlancR1 calibration constant from FLIR file	21106.77
PR2	PlancR2 calibration constant from FLIR file	0.0125
raw_obj	cacluated object distance	-
PO	PlankO calibration constant from FLIR file	-7340
PF	PlankF calibration constant from FLIR file	1

본 연구는 탐지에 유리한 이미지를 생성하는 것 뿐만 아니라, 발열 특성을 학습에 반영하여 모델 학습의 효율을 높이고자 한다. 이에 따라 다음과 같은 과정을 거쳐 합성 이미지도 생성한다.

첫째, 각 이미지에 대한 발열 수치를 [0,1]사이로 정규화 한다. 이를 통해 한 이미지 내에서 상대적으로 온도가 낮은 부위는 하얀색으로, 온도가 높은 부위는 검은색으로 표현한다. 이를 흑백 열화상 이미지로 지칭한다.

둘째, 추출된 실화상 이미지와 열화상 이미지의 해상도를 맞추기 위해 상대적으로 해상도가 큰 실화상 데이터를 중앙점을 기준으로 640x480 픽셀 이미지로 크롭(Crop)한다.

셋째, 흑백 열화상 이미지와 크로핑 한 실화상 이미지를 3:7의 비율로 값을 섞는다. 비율은 실험적으로 유추되었다.

Fig. 5은 합성 이미지 생성과정에 따른 각 단계별 이미지들을 예시로 보여준다. 이렇게 실험에 필요한 3종류의 이미지 그룹을 생성하고, 기존 탐지 사용 되었던 원본 이미지까지 포함하여 총 4종류의 이미지를 준비하였다.

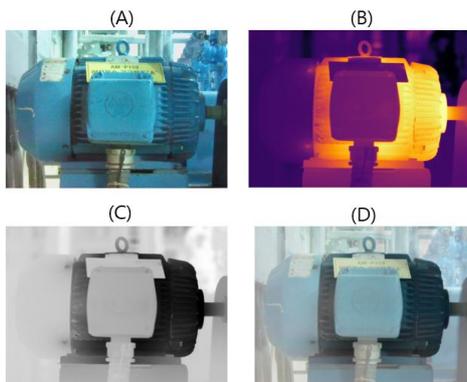


Fig. 5. (a) Cropped RGB image (b) Thermal iamge (c) Normalized thermal image (d) Fusion image

2.2.3 딥러닝 모델 학습 및 탐지

딥러닝 기반 발열 이상 탐지를 위한 모델은

Faster-RCNN이 사용되었으며, 백본(Backbone)은 Resnet101이 사용되었다. 실험 데이터는 한국수력원자력발전소의 5개 발전소에서 촬영 된 열화상 이미지 약 6500장이 사용되었으며, 측정 된 설비는 회전 설비 (Motors) 6종, 전기 설비(Electrics) 26종, 기타 설비 (ETC) 1종으로 총 34종이 측정되었다. Table 3은 대표 설비 이미지 3종류를 보여주고 있다.

Table 3. Data Class sample

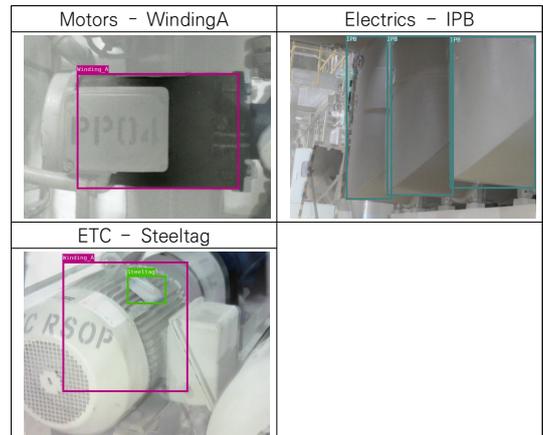


Fig. 6은 Faster-RCNN의 학습의 전체 개요를 나타낸다. Faster-RCNN은 크게 Pre-Processing, Region Proposal Network(RPN), Classification Layer로 구성되어 있으며 각 알고리즘의 역할은 다음과 같다 [10,11].

Pre-Processing에서는 이미지 스케일링과 평균 픽셀 값을 추출한다. 본 실험은 720x360 해상도기준 이나 세로 촬영 이미지 및 발전소 환경에 의해 이미지 크기가 다른 경우가 발생하기에 전처리를 필요로 한다.

RPN은 Faster-RCNN에서 핵심적인 요소이다. 본 네트워크는 CNN을 통해 추출한 특징 맵(Feature map)에서 고정된 크기와 위치를 가진 앵커를 만들어 회귀(Regression)와 분류(Classification) 예측값을 계산하여 예측값이 높은 바운딩 박스(Bounding Box)를 ROI(Region of Interest)로서 추출한다.

Classification Layer는 RPN에서 추출한 ROI에 대하여 Convolutional Feature Map을 사용하여 Grid Points Sample Feature Maps를 생성하고 풀링(Pooling)을 평균 4번 거쳐 일차원 피쳐 벡터를 생성한다. 해당 벡터는 각 클

래스에 대한 Class Probability를 담고 있다.

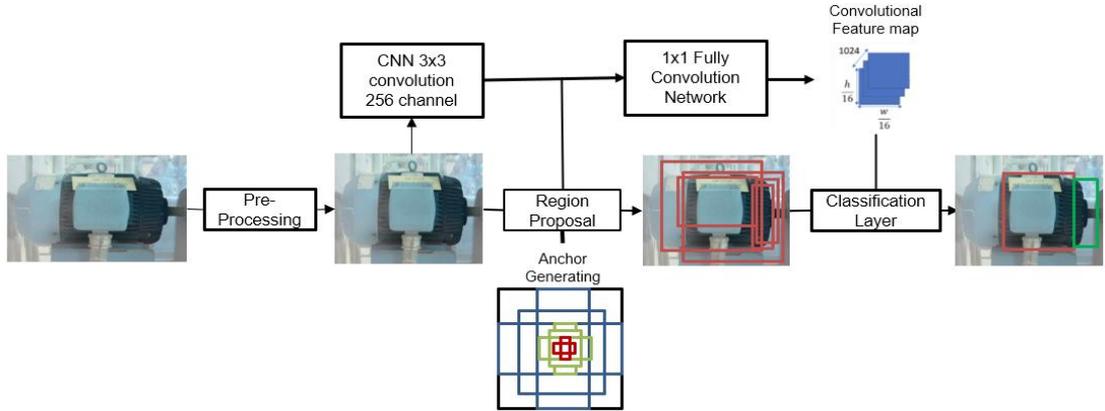


Fig. 6. Faster R-CNN Summary Graph

본 실험에서 사용된 Resnet152 하이퍼 파라미터 (Hyper Parameter)는 Table 4과 같다.

Table 4. Experiment Environment

Parameter	Value
Anchor_ratio	[(1,2),(1,1),(2,1)]
Anchor_size	[128,256,512]
Learning_rate	0.001
Momentum	0.9
Pooler_mode	Align pooling
Weight_decay	0.0005
Warmup_factor	0.3333

2.2.4 불량 데이터 재활용

한국수력원자력발전소는 정밀 이상 진단을 위한 열화상 이미지를 저장하였다. 담당자의 발전에 따라 해당 이미지들을 활용하려 하였으나, 서론에 소개된 문제들로 인해 많은 이미지가 탐지 실패로 인한 불량 판정을 받고 재촬영이 요구되었기에 경제적 손실이 발생하였다.

이에 본 연구는 모델 학습 및 평가에 사용되는 이미지 6500장 중 약 300장을 불량 판정 이미지로 구성하여, 기존 설비 탐지 불가 판정을 받은 이미지에서 설비 탐지를 시도한다. 이를 통하여 불량 데이터를 재활용한다.

3. 결론

3.1 실험 결과

Table 5. Result of Average-Precision

	Raw	Thermal	RGB	Fusion
Mean	0.505	0.520	0.73	0.67
Bearing_A	0.692	0.675	0.81	0.809
Bearing_B	0.62	0.606	0.815	0.816
Bearing_C	0.564	0.709	0.697	0.716
Bearing_D	0.909	0.984	0.892	0.814
Winding_A	0.798	0.705	0.894	0.806
Winding_B	0.51	0.486	0.703	0.439
Winding_C	0.68	0.636	0.696	0.573
PCBboard	0.416	0.348	0.758	0.612
SCR	0.545	0.0	1	1
Cable	0.186	0.255	0.65	0.49
Circuit breaker	0.402	0.69	0.891	0.803
Fuse	0.427	0.408	0.706	0.696
Resistor	0.281	0.241	0.586	0.505
Busbar	0.211	0.171	0.67	0.663
CT	0.554	0.321	0.466	0.53
PT	0.449	0.863	1	1
IPB	0.595	0.591	0.67	0.55
Lightning arrester	0.704	0.775	0.813	0.711
MOF	0.72	0.797	0.8	0.818
Insulator	0.785	0.794	0.799	0.663
HVcable	0.484	0.451	0.706	0.624
Ground	0.288	0.376	0.721	0.436
Oilpump	0.707	0.79	0.786	0.777
Nground	0.58	0.505	0.803	0.565
Transfor merbody	0.636	0.272	0.778	0.586
Capacitor	0.45	0.09	0.727	0.617
Coolingfan	0.26	0.498	0.693	0.43
Relay	0.0	0.545	0.06	0.909
HVBushing	0.409	0.0	1	0.545
Trans_A	0.476	0.272	0.778	0.691
Trans_B	0.499	0.798	0.807	0.825
Trans_C	0.42	0.727	0.666	0.542
Steeltag	0.18	0.31	0.4	0.418

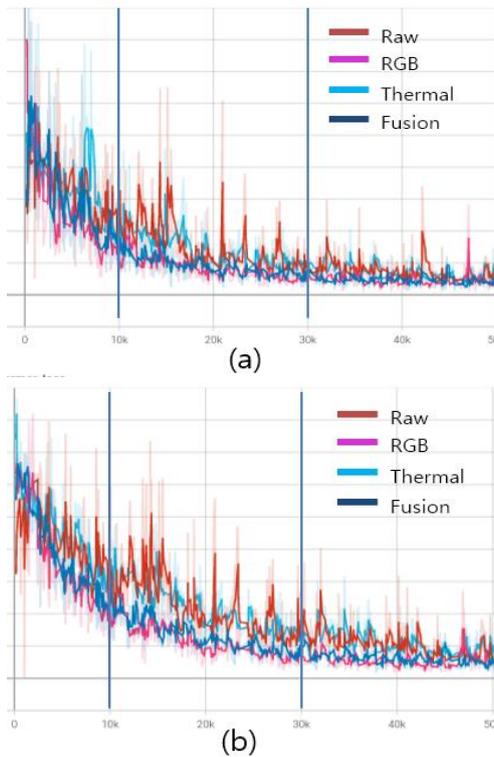


Fig. 7. Loss functions graph (a) class proposal loss graph. (b) class transformer loss

Table 5는 설비 클래스 별 mAP와 그에 따른 평균 mAP값을 보여주고 있다. 실험 결과에 따르면 기존 데이터 그룹은 mAP가 0.505이며, 합성 이미지 그룹은 0.67이다. 즉 기존 방식에 비해 본 연구에서 제안한 방법은 평균 mAP를 0.17 향상시켰다.

또한 Fig. 7에서 학습 초반부에서 손실 함수가 빠르게 줄어드는 모습을 보이고 있는데, 이는 기존 데이터 그룹에 비해 데이터의 일관성이 있어, 학습 효율이 좋은 것으로 해석 된다.

지표를 통해 합성 이미지 방식의 개선점을 찾아보면, RGB 이미지 그룹이 합성 이미지 그룹보다 성능 향상이 더 좋은 것이 있다. 이는 두 가지 이유가 유추된다.

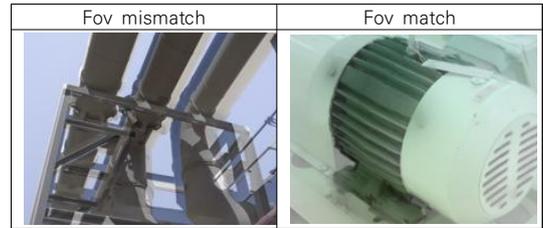
첫 번째 이유는 배경과 설비의 발열 정도가 비슷하면 흑백 이미지 합성으로 인해 경계선이 뭉개져 특징을 손실하는 문제다. 이는 HVbushing, Ground에서 발견할 수 있는데, 두 설비의 공통점은 야외에 존재하며, 방열재질로 설비 전체가 감싸져 있다는 것이다.

두 번째 Fov(Field of view) 이슈이다. 이는 실화상 이미지 탐지율이 합성 이미지보다 좋음에도 실화상 이

미지를 이용한 이상 진단이 부적합한 원인과 동일하다.

열화상 렌즈와 실화상 렌즈간의 물리적 거리로 인해, 렌즈를 확대하거나 축소해서 촬영할 때 FoV의 차이가 발생하는 문제이다. 이는 Table 6에서와 같이 카메라 모델 및 렌즈 조절로 인해 이미지마다 다른 정도값을 지닌다.

Table 6. View gap of fusion image



본 연구에서는 FLIR T660에 적합한 수치 조절을 메타 데이터 해석 과정에서 진행하였기에 FoV 차이를 최소화하는 패러미터 값을 실험적으로 취득하였으나, 측정 장치가 달라지면 새로운 값을 구해야하기에 본질적인 해결은 추후 과제로 남아있다.

불량 데이터 재활용에 대한 실험은 다음과 같다. 학습과 평가의 데이터 사용 비율이 8:2며 이에 따라 불량 판정 받은 테스트 데이터는 60장이다. 이 중 39장이 실비 탐지에 성공 했으며, 이는 폐기 예정 이미지 중 50% 이상을 발열 진단에 사용 할 수 있어 불필요한 재촬영을 막고 데이터 활용성을 크게 개선 할 수 있다.

대표적인 성공 샘플과 실패 예시는 Table 7에 나타난다.

Table 7. Bad data usage result example

Image	Detection
	True
	True
	False

3.2 결론 및 고찰

본 연구는 한국수력원자력발전소의 딥러닝 기반 발열 설비 탐지의 낮은 정확도를 향상 시키기 위한 방법을 제안하였다. 또한 기존 불량 데이터 판정을 받은 데이터를 활용하여 불필요한 추가 측정을 피하고, 인력 및 경제적 효율을 증가 시키는 방법을 모색하였다.

제안한 방법은 기존 방식에 비해 분명한 정확도 향상을 보였으며, 손실 함수 분석을 통해 학습 효율 또한 입증하였다.

그러나 이미지 촬영을 위한 센서 간의 FOV 차이, 단 순 합성으로 인해 학습 특징을 손실하는 문제가 발생하였으며 이를 해결하기 위한 추후 연구가 진행되어야 할 것이다.

REFERENCES

[1] J. Ma, Y. Ma & C. Li. (2019). Infrared and visible image fusion methods and applications: A survey. *Information Fusion*, (45), 153-178.

[2] B. B. Kang & J. Y. Kim. (2016). Anomaly diagnosis method using thermal image histogram signal characteristics. *Proceedings of the Korean Urban Railway Association*, 4(3), 521-528.

[3] K. H. Kim, S. S. Park, H. T. Lim, S. J. Lee & Y. S. Kim. (2019). Detecting leaks in old sewage pipes using thermal imaging information of an unmanned aerial system. *Abstract of the Korean Society of Agricultural Engineering Conference*, 159-159.

[4] Z. Guo, W. Liao, Y. Xiao, P. Veelaert & W. Philips. (2019). Deep learning fusion of RGB and depth images for pedestrian detection. *The 30th British Machine Vision Conference* (pp. 1-13). Cardiff : The BMVA.

[5] S. K. Lee, C. Y. Yoon, K. D. Moon, & C. G. Kim. (2020). A study on image synthesis-based training data augmentation for single-step detection method. *Korean Information Processing Society*, 27(1), 446-450.

[6] S. Ren, K. He, R. Girshick & J. Sun. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, 28, 91-99.

[7] W. Minkina & S. Dudzik. (2009). *Infrared Thermography : Errors and Uncertainties*. London : John Wiley & Sons

[8] P. Harvey. (n. d). *ExifTool by Phil Harvey (Online)*. <https://exiftool.org>

[9] K. He, G. Gkioxari, P. Dollár & R. Girshick. (2017). Mask r-cnn. *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969). Cambridge : IEEE

[10] X. Wang, M. Yang, S. Zhu & Y. Lin. (2013). Regionlets for generic object detection. *Proceedings of the IEEE international conference on computer vision* (pp. 17-24). Cambridge : IEEE.

[11] H. J Kim, E. Dunn & J. M. Frahm. (2017). Learned contextual feature reweighting for image geo-localization. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 3251-3260). Cambridge : IEEE.

신 기 철(Ki-Chul Shin)

[학생회원]



- 2020년 2월 : 인하대학교 정보통신 공학과(학사)
- 2021년 2월 ~ 현재 : 인하대학교 전기컴퓨터공학과 석사 과정
- 관심분야 : 인공지능, 신호 처리
- E-Mail: kichoul641@gmail.com

이 준 수(Jun-Su Lee)

[정회원]



- 2011년 2월 : 인하대학교 기계공학과(학사)
- 2016년 8월 : 인하대학교 기계공학과(석사)
- 2018년 2월 ~ 현재 : 인하대학교 기계공학과 박사 과정
- 관심분야 : 열 처리, 이상 진단
- E-Mail: corean293@naver.com

김 주 식(Ju-Sik Kim)

[정회원]



- 20011년 5월 ~ 현재 : 한국수력원자력 디지털혁신추진단
- 관심분야 : 인공지능, Digital Twin, Predictive Maintenance
- E-Mail: eleckimjs@khnp.co.kr

김 주 형(Ju-Hyung Kim)

[정회원]



- 2005년 12월 : Royal Institute of Technology(박사)/전자공학과
- 2008년 4월 ~ 2009년 8월 :인하대학교 연구교수
- 2013년 3월 ~ 현재 : 인하대학교 교수
- 관심분야 : 반도체, MEMS, 열제어
- E-Mail : joohyung.kim@inha.ac.kr

권 장 우(Jang-Woo Kwon)

[정회원]



- 1996년 8월 : 인하대학교 정보공학과(박사)
- 1998년 3월 : 특허청 사무관
- 2009년 3월 : 동명대학교 부교수
- 2012년 3월 : 경원대학교 부교수
- 2012년 3월 ~ 현재 : 인하대학교 교수

- 관심분야 : HCI, 교통, 인공지능
- E-Mail : jkwon@inha.ac.kr